




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE ULTRAZVUKOVÝCH SEKVENCÍ

ULTRASOUND IMAGE SEQUENCE SEGMENTATION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

VLADIMÍR GALLO

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. MARTIN MÉZL

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

Student: Vladimír Gallo

ID: 136469

Ročník: 3

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Segmentace ultrazvukových sekvencí

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem perfuzního zobrazení pomocí kontrastní ultrasonografie. 2) Prostudujte techniky používané pro segmentaci ultrazvukových sekvencí a vyberte vhodné metody pro segmentaci dat. 3) Vybrané metody naprogramujte v programovém prostředí Matlab a otestujte na uměle vytvořených a fantomových datech. 4) Práci rozšiřte o uživatelské grafické rozhraní (GUI), ve kterém bude možné zadávat parametry jednotlivých metod a zobrazovat výsledek segmentace. 5) Diskutujte možnosti a výsledky jednotlivých metod v závislosti na vlastnostech obrazů.

DOPORUČENÁ LITERATURA:

- [1] NOBLE, J. A., BOUKERROUI, D. Ultrasound Image Segmentation: A Survey. IEEE: Transactions on Medical Imaging 2006, vol. 25, No. 8, pg. 987-1010.
[2] JAN, J. Medical Image Processing, Reconstruction and Restoration: Concepts and Methods. Boca Raton: Taylor & Francis Group, 2006. ISBN: 0-8247-5849-8 (vybrané kapitoly).

Termín zadání: 11.2.2013

Termín odevzdání: 31.5.2013

Vedoucí práce: Ing. Martin Mézl

Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

V tejto práci sa nachádza základný popis princípu ultrasonografie, prehľad využívaných zobrazovacích módov, princíp kontrastného zobrazovania a prehľad základných segmentačných techník. Z uvedených metód boli v programe Matlab implementované segmentačné metódy založené na hranovej detekcii a narastaní oblasti. Navrhnuté algoritmy boli následne otestované na umelých a fantómových obrazových dátach.

Kľúčové slová

Ultrazvuk, Ultrasonografia, Perfúzia, Segmentácia, Hranová detekcia, Metóda narastania oblastí, Grafické užívateľské rozhranie

Abstract

This paper presents basic principles of ultrasonography, review of different modes of medical ultrasound imaging, principle of contrast-enhanced ultrasonography and review of basic techniques of image segmentation. The individual methods based on edge detection and region growing were implemented in Matlab. The performance of algorithms were tested in each category using synthetic and phantom image data.

Key words

Ultrasound, Ultrasonography, Perfusion, Segmentation, Edge-Based Detection, Region Growing Method, Graphical User Interface

Bibliografická citácia:

GALLO, V. *Segmentace ultrazvukových sekvencí*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. 48 s. Vedoucí bakalářské práce Ing. Martin Mézl.

Prehlásenie

Prehlasujem, že svoju bakalársku prácu na tému „Segmentácia ultrazvukových sekvencií“ som vypracoval samostatne pod vedením vedúceho bakalárskej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej bakalárskej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto bakalárskej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11a nasledujúceho autorského zákona č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon) v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovení časti druhej, hlavy VI. díl 4 Trestního zákoníku č. 40/2009Sb.

V Brne dňa

.....

podpis autora

Pod'akovanie

Rád by som sa poďakoval vedúcemu bakalárskej práce pánovi Ing. Martinovi Mézlovi za odbornú pomoc, konzultácie, cenné rady a veľkú trpezlivosť pri spracovaní mojej bakalárskej práce.

V Brne dňa

.....

podpis autora

Obsah

Úvod	8
1 Ultrasonografia	9
1.1 Fyzikálna podstata zobrazovania ultrazvukom	9
1.2 Ultrazvukové metódy zobrazovania štruktúry	11
1.2.1 2D zobrazovanie	11
1.2.2 M – zobrazovanie	12
1.2.3 3D zobrazovanie	12
1.3 Ultrazvukové metódy zobrazovania rýchlosti toku krvi - dopplerovské metódy	12
1.3.1 Spojité dopplerovské zobrazovanie – prietokomery	12
1.3.2 Pulzné dopplerovské metódy	13
1.4 Kontrastná ultrasonografia	13
1.4.1 Princíp zobrazovania	14
1.4.2 Perfúzne zobrazovanie	15
2 Segmentácia medicínskych obrazových dát	16
2.1 Segmentácia prahovaním	16
2.2 Segmentácia založená na hranovej detekcii	17
2.2.1 Hranové detektory	18
2.2.2 Houghova transformácia	20
2.3 Regiónovo orientovaná segmentácia	21
2.3.1 Segmentácia narastaním oblasti	21
2.3.2 Segmentácia zlučovaním oblastí	22
2.3.3 Segmentácia delením a zlučovaním oblastí	23
2.3.4 Segmentácia algoritmom rozvodia	24
2.4 Segmentácia pomocou pružných a aktívnych kontúr	25
2.5 Využitie matematickej morfológie v segmentácii	26
2.6 Metódy segmentácie kontrastných ultrazvukových sekvencií	28
3 Implementácia vybraných segmentačných metód v programovom prostredí Matlab	30
3.1 Predspracovanie obrazu	32

3.2	Segmentácia založená na hranovej detekcii.....	32
3.3	Segmentácia založená na narastaní oblasti	33
3.4	Finálne úpravy segmentácie.....	35
3.5	Vzhľad a ovládanie grafického užívateľského rozhrania	36
4	Dosiahnuté výsledky.....	39
	Záver.....	42
	Literatúra	43
	Zoznam príloh	45
A	Elektronická časť bakalárskej práce	46
A.1	Program a testovacie dáta	46
A.1.1	Program a grafické užívateľské rozhranie	46
A.1.2	Pomocné funkcie	46
A.1.3	Testovacie dáta	46
A.2	Elektronická verzia bakalárskej práce	46
B	Vzhľad grafického užívateľského rozhrania.....	47
C	Odporúčania pre používanie programu.....	48

Úvod

Segmentácia obrazu je základným krokom v algoritme analýzy a spracovania obrazu. S rozvojom digitálnej techniky nachádza segmentácia široké uplatnenie. Príkladom môžu byť priemyselné aplikácie, bezpečnostné systémy, digitalizácia fyzických dokumentov, či digitálna fotografia.

Významnou oblasťou aplikácie sú medicínske obrazové dáta, pretože ich segmentácia môže výrazne uľahčiť diagnostiku a tým urýchliť celý proces zdravotnej starostlivosti. Práca sa zaoberá segmentáciou dát jedného z najrozšírenejších diagnostických zobrazovacích systémov v rade lekárskeho odborov, ktorým je ultrasonografia.

Vďaka dobrej prenikavosti ultrazvuku živými tkanivami je ultrasonografia pri vhodne zvolených intenzitách bezrizikovým diagnostickým vyšetrením, a preto býva prvou voľbou v racionálnom diagnostickom algoritme. Ďalšími výhodami ultrasonografie sú relatívne nízke náklady na obstaranie a prevádzku ultrasonografu a rýchlosť vyšetrenia.

Značnou nevýhodou ultrazvukových zobrazovacích systémov je nízka kvalita obrazu. Z dôvodu prítomnosti šumu typu speckle a artefaktov spôsobených atenuáciou je otázka spoľahlivosti segmentácie ultrasonografických dát zložitejšia ako pri dátach z iných zobrazovacích systémov, a preto automatická segmentácia anatomických štruktúr v ultrasonografii zostáva naďalej veľkou výzvou. Podobne ako v iných zobrazovacích metódach, aj v ultrasonografii sa stále viac používajú kontrastné látky, pomocou ktorých je možné hodnotiť prekrvenie orgánov. Perfúzia je významnou vlastnosťou tkaniva, ktorá sa mení v závislosti na mnohých fyziologických a patologických procesoch.

V úvode sa práca venuje princípu ultrasonografických metód a perfúzneho zobrazenia pomocou kontrastnej ultrasonografie.

Práca ďalej poskytuje stručný prehľad základných segmentačných techník, z ktorých boli v programe Matlab realizované segmentačné metódy založené na hranovej detekcii a narastaní oblastí. Metódy sú následne testované na fantómových a umelo vytvorených obrazových dátach. Pre jednoduché užívateľské ovládanie a testovanie navrhnutých algoritmov bol program doplnený o grafické užívateľské rozhranie.

1 Ultrasonografia

V ultrasonografii je signálom, nositeľom informácie, ultrazvuk. Jedná sa o mechanické vlnenie hmotného prostredia s frekvenciami vyššími ako 20kHz, teda nad hranicou počuteľnosti zdravého ľudského ucha. Ultrazvuk sa v medicíne pre účely diagnostického zobrazovania začal používať začiatkom 50. rokov 20. storočia. Základom pre rozvoj skupiny metód zobrazujúcich morfológiu tkanív bola ultrazvuková defektoskopia používaná v priemysle ako nedeštruktívna metóda dôkazu materiálových väd. Táto metóda bola založená na detekcii rozhraní dvoch prostredí s rôznymi akustickými impedanciami. Na detegovanie týchto akustických rozhraní sa najčastejšie používala impulzná odrazová metóda. Princíp metódy spočíval vo vysielaní veľmi krátkych ultrazvukových impulzov, ktoré boli po odraze na akustických rozhraniach zachytené elektroakustickým meničom. Ten slúžil ako zdroj a zároveň detektor ultrazvukových vln [1].

Druhá skupina ultrazvukových metód využíva Dopplerov jav, ktorý vyjadruje frekvenčný posun pri vzájomnom pohybe zdroja vlnenia a jeho „pozorovateľa“. Tieto metódy sa používajú na meranie rýchlosti toku krvi a sledovanie pohybujúcich sa akustických rozhraní ako sú napríklad srdcové chlopne.

Vďaka dobrej prenikavosti ultrazvuku živými tkanivami je ultrasonografia pri vhodne zvolených intenzitách bezrizikovým diagnostickým vyšetrením, a preto býva prvou voľbou v racionálnom diagnostickom algoritme [8]. Ďalšími dôvodmi prečo je ultrasonografia najrozšírenejšou diagnostickou zobrazovacou metódou v rade lekárskeho odborov sú relatívne nízke náklady na obstaranie a prevádzku ultrasonografu a rýchlosť vyšetrenia [2].

1.1 Fyzikálna podstata zobrazovania ultrazvukom

V diagnostike sa frekvencia ultrazvuku pohybuje v rozsahu 1 – 10 MHz. Generovanie tohto vysokofrekvenčného vlnenia je založené na nepriamom piezoelektrickom jave. Ten spočíva v tom, že privedenie napätia na protiľahlé povrchy určitých materiálov vyvolá ich deformáciu. Ak je toto napätie striedavé, doštička z piezoelektrického materiálu kmitá s jeho frekvenciou. Napätie privádzané z generátoru má frekvenciu nastavenú na vlastnú rezonančnú frekvenciu doštičky, ktorá je daná jej rozmermi a mechanickými vlastnosťami. Pri detekcii ultrazvuku je situácia opačná. Deformáciou piezoelektrického materiálu mechanickým vlnením vzniká na opačných koncoch jeho takzvanej elektrickej osy elektrický náboj.

Vo väčšine sond ultrasonografických prístrojov slúži ako generátor a detektor ultrazvuku ten istý element. Ten pri generovaní ultrazvuku mení elektrický signál na akustický a pri detekcii zase akustický signál na elektrický. Preto sa všeobecne označuje ako ultrazvukový menič. Sonden sa môžu skladať z jedného alebo viacerých takýchto meničov. Na výrobu meničov sa používajú napríklad kryštály oxidu kremičitého, ktoré sa špeciálne vybrúsia alebo keramické materiály pripravené umelo.

Piezoelektrický menič ultrasonografu generuje impulzy trvajúce niekoľko milisekúnd s frekvenciou opakovania 100 - 1000 Hz. Každý z týchto generovaných impulzov je možné charakterizovať určitou intenzitou I_0 , frekvenciou f_0 a časom vzniku t_0 . Impulz preniká vyšetrovanými tkanivami a na každom rozhraní dvoch tkanív s rozdielnymi akustickými impedanciami sa čiastočne odrazí. Vzniknuté odrazené vlny s intenzitou I_i , frekvenciou f_i a časom, kedy došlo k ich zaregistrovaniu meničom t_i , kde $i = 1, 2, \dots, n$, a n je počet rozhraní, na ktorých sa vygenerovaný impulz sčasti odrazil, sú týmto meničom opäť zaregistrované. Za zjednodušeného predpokladu skoro nemennej rýchlosti šírenia ultrazvuku v mäkkých tkanivách nám časové oneskorenie umožňuje jednoznačne určiť vzdialenosť rozhrania, na ktorom došlo k odrazu od sondy. Vzdialenosť jednotlivých rozhraní je potom definovaná vzťahom:

$$d_0 = 2 \cdot c \cdot (t_i - t_0), \quad (1.1)$$

kde $i = 1, \dots, n$ a $c = 1500 \text{ m} \cdot \text{s}^{-1}$.

Na každom rozhraní dvoch prostredí s rozdielnymi akustickými impedanciami sa časť energie odrazí a časť preniká do druhého prostredia podľa vyššie uvedeného vzťahu. Na tomto princípe je založené zobrazovanie mäkkých tkanív ultrazvukom. S hĺbkou prieniku ultrazvuku do tkaniva klesá jeho intenzita podľa vzťahu:

$$I = I_0 \cdot e^{-\alpha d}, \quad (1.2)$$


kde I_0 je intenzita počiatočná, $\alpha [\text{m}^{-1}]$ je absorpčný koeficient a $d [\text{m}]$ je hrúbka vrstvy tkaniva, za ktorou je intenzita vlnenia I . Zoslabenie ultrazvuku absorpciou nemá v diagnostike žiadny prínos, ba naopak, treba ho kompenzovať. Kompenzácia sa realizuje pomocou špeciálnych zosilňovačov nazývaných TGC - Time Gain Compensation. Zosilňovač kompenzuje straty energie dané absorpciou. Teda s čím väčším oneskorením bol odrazený impulz registrovaný (čím bolo miesto jeho odrazu hlbšie), o to väčšie musí byť jeho zosilnenie.

Podľa spôsobu zobrazenia ech (odrazov) registrovaných meničom sa rozlišuje zobrazenie A a zobrazenie B.

A zobrazenie (A-scan, A-mode, A-scope) je založené na amplitúdovej modulácii signálu. Jednotlivé zaregistrované odrazy sú na monitore zobrazené ako impulzy na časovej osi, ktorá býva ociahovaná jednotkami vzdialenosti. Veľkosť amplitúdy jednotlivých impulzov zodpovedá intenzite odrazeného vlnenia. Toto zobrazenie možno považovať za jednorozmerné. V súčasnosti sa používa len na presné biometrické merania, v oftalmológii, a v ultrazvukovej defektoskopii.

B zobrazenie (B-scan, B-mode, Bscope) využíva jasovú moduláciu (B – brightness = jas). Ultrazvukové vlny odrazené od jednotlivých akustických rozhraní sú zobrazované na monitore ako pixely s rôznymi hodnotami jasů. Poloha týchto bodov, podobne ako

v A zobrazení poloha impulzov, zodpovedá polohe jednotlivých rozhraní, na ktorých došlo k odrazu. Intenzita odrazených vln je interpretovaná ako jas týchto bodov, pričom väčšinou platí, že čím je intenzita odrazenej vlny väčšia, tým je jas zodpovedajúceho bodu vyšší. To znamená, že takzvané echogénne štruktúry s dobrou odrazivosťou sú znázornené najjasnejšie a naopak štruktúry, ktoré sú homogénne a ultrazvuk dobre neodrážajú v dôsledku absencie akustických rozhraní, sú znázornené s menším jasom. Zobrazenie B je podstatou všetkých v dnešnej dobe používaných ultrazvukových metód zobrazujúcich štruktúru mäkkých tkanív s výnimkou už spomínanej oftalmológie [2].



Obr. 1.1 Princíp A a B zobrazenia [2].

1.2 Ultrazvukové metódy zobrazovania štruktúry

1.2.1 2D zobrazenie

Najrozšírenejším zobrazením je takzvané 2D (D – dimension) – dvojrozmerné zobrazenie rezu mäkkými tkanivami tela. Rovina rezu je daná tvarom ultrazvukového poľa generovaného zvoleným typom ultrazvukovej sondy. Pole môže byť tvorené mechanicky – rotáciou jedného alebo niekoľkých ultrazvukových meničov v rovine zobrazenia alebo elektricky, keď je sonda tvorená niekoľkými miniatúrnymi meničmi a výsledné ultrazvukové pole je dané ich vzájomným usporiadaním a synchronizovanou aktiváciou.

Ultrazvukové pole mechanických sond má vejárovitý tvar s úzku základňou. Elektronické sondy ponúkajú niekoľko variantov: sektorové pole s úzku základňou, sektorové pole so širokou základňou – takzvané kovexné sondy a lineárne ultrazvukové pole. Sonda s úzku základňou sektorového poľa sa využíva na zobrazovanie štruktúr, ktoré sú v čiastočnom zákryte kostí, napríklad pri vyšetrení srdca, kedy je sonda umiestnená do oblasti medzi rebrami.

Pre účely merania rozmerov je najlepšou voľbou sonda s lineárnym poľom s možnosťou zavedenia ortogonálneho systému súradníc.

1.2.2 M – zobrazenie

Jedná sa o modifikáciu základného B zobrazenia. Využíva sa pri sledovaní pohybujúcich sa štruktúr. Najčastejšie ide o sledovanie pohybov chlopní či srdcovej steny v echokardiografii. Cieľom metódy je zobrazit' polohu jedného bodu (v skutočnosti vymedzenej plochy) pohybujúcej sa štruktúry v závislosti na čase. Jedná sa o jednorozmerné zobrazenie, pretože zmena polohy je sledovaná iba na priamke danej smerom šírenia ultrazvukovej vlny.

1.2.3 3D zobrazenie

Tento spôsob zobrazenia vyžaduje špeciálny typ sondy, ktorá je schopná generovať trojrozmerné ultrazvukové pole. Väčšinou sa využíva kmitavý pohyb klasického 2D ultrazvukového poľa. Existujú však aj iné prístupy ako napríklad snímanie dát rotáciou ultrazvukového poľa, snímanie voľnou rukou a podobne. Tieto metódy sa však dajú uplatniť len za predpokladu, že zobrazovaná scéna je stacionárna. Výsledný 3D obraz je rekonštruovaný podobnými algoritmami ako v iných 3D zobrazovacích systémoch [2].

1.3 Ultrazvukové metódy zobrazenia rýchlosti toku krvi - dopplerovské metódy

Ako už bolo v úvode kapitoly spomenuté, dopplerovské metódy vychádzajú zo vzťahu zmeny frekvencie. Používajú sa na meranie rýchlosti pohybujúcich sa štruktúr, ktorými môžu byť v prípade merania rýchlosti toku krvi erytrocyty. Dopplerovské metódy je možné rozdeliť na dve skupiny podľa toho, či pracujú v spojitom alebo pulznom režime. Obidva tieto režimy majú svoje výhody aj nevýhody.

1.3.1 Spojité dopplerovské zobrazenie – prietokomery

Spojité dopplerovské zobrazenie je charakteristické použitím oddeleného vysielača a prijímača ultrazvukového vlnenia. Ako vyplýva z názvu, vysielač s jedným meničom spojitou generuje akustický signál a preto nemôže slúžiť aj ako prijímač. Zhodou okolností je frekvenčný posun pre meranie rýchlosti toku krvi v ľudskom tele v počuteľnej oblasti, a preto majú dopplerovské prietokomery aj akustický výstup. Základným výstupom je však zobrazenie závislosti rýchlosti toku krvi na čase. Výhodou prietokomerov je ich jednoduchosť a s tým spojená cenová dostupnosť. V porovnaní s pulznými metódami nemajú možnosť zobrazit' usporiadanie a umiestnenie, a teda ani vzdialenosť sledovaných ciev, čo je ich značnou nevýhodou. Meranie absolútnej veľkosti rýchlosti je tiež len orientačné, pretože

pre výpočet rýchlosti nie je možné zistiť veľkosť uhla, ktorý zvierá vysielané vlnenie s vyšetrovanou cievou. Z rovnakých dôvodov nie je v prípade dvoch prekrývajúcich sa ciev možné zistiť, v ktorej z nich vlastne rýchlosť krvi meriame.

Prietokomery sa prevažne používajú na sledovanie toku krvi v horných a dolných končatinách.

1.3.2 Pulzné dopplerovské metódy

Pulzné dopplerovské metódy sa väčšinou využívajú v kombinácii s ultrazvukovými zobrazovacími metódami, pretože používajú rovnaké sondy, ktoré môžu pracovať v rôznych režimoch. Ich kombináciou sú takzvané duplexné či triplexné režimy zobrazovania. Vďaka prerušovanému – pulznému generovaniu ultrazvukového vlnenia je možné sledovať zároveň časový aj frekvenčný posun odrazeného vlnenia, čo znamená, že meranie poskytuje informáciu o rýchlosti toku aj o polohe meraného miesta. Z toho vyplýva, že prístroj je schopný odčítať uhol, ktorý zvierá smer šírenia ultrazvukového vlnenia a smer toku krvi. Vymedzením meranej oblasti je možné sledovať rozloženie rýchlosti v cieve. Táto oblasť sa označuje ako vzorkovací objem. Podľa toho, akým spôsobom je informácia o rýchlosti zobrazená na monitore, sú pulzné dopplerovské zobrazenia rozdelené do troch skupín.

Dopplerovská metóda mapovania prietoku farbou

Rýchlostiam toku krvi v cievach je priradená farba. Najčastejšie sa používajú rôzne odtiene červenej pre rýchlosti laminárneho toku krvi smerom ku sonde a odtiene modrej pre rýchlosti toku krvi v smere od sondy. Turbulentné prúdenie je väčšinou znázornené zelenou farbou. Tento druh zobrazenia sa využíva v kombinácii s 2D zobrazením k farebnému zvýrazneniu tokov v sledovanej oblasti.

Spektrálne dopplerovské zobrazenie

Táto metóda umožňuje v zvolenom reze cievy (vzorkovacím objeme) zobrazovať graf rozloženia celého spektra rýchlostí v závislosti na čase samostatne mimo 2D okno. Na zvislú os grafu je vynesená buď frekvencia [Hz] alebo priamo rýchlosť [$m \cdot s^{-1}$], prípade oboidve.

Farebné dopplerovské zobrazenie energie

Tento spôsob zobrazuje nielen rýchlosť – frekvenčný posun, ale aj intenzitu, a teda energiu ultrazvukových vln odrazených od pohybujúcich sa krvných elementov. Veľkosť tejto energie je úmerná počtu krviniek, ktoré sa v sledovanom objeme pohybujú. Farebný odtieň pixelu na monitore zodpovedá veľkosti tejto energie [2].

1.4 Kontrastná ultrasonografia

Podobne ako v iných zobrazovacích metódach, aj v ultrasonografii sa stále viac používajú kontrastné látky. Ultrasonografické kontrastné látky sú tvorené mikrobublinami plynu, ktoré

zvyšujú počet odrazov zaznamenaných meničom sondy vďaka rezonácii s dopadajúcim ultrazvukovým vlnením.

Tieto kontrastné látky je možné rozdeliť z hľadiska využitia do troch skupín.

Do prvej z nich patria kontrastné látky s intrakavitálnym použitím v gynekologických a urologických aplikáciách.

Druhú aplikačnú skupinu tvorí využitie orgánovo špecifických kontrastných látok. Táto problematika je však stále vo fáze experimentu predovšetkým v oblasti nádorov pečene.

Tretiu skupinu tvoria intravaskulárne aplikácie, v ktorých bol v poslednej dobe zaznamenaný najväčší rozmach. Mikrobubliny sú vďaka svojej veľkosti 1 – 10 μm schopné prenikať pľúcnymi kapilármi, teda po intravenóznom podaní prenikajú zo žilného splavu cez malý obeh (pľúcny) až do veľkého systémového obehu [4].

1.4.1 Princíp zobrazenia

Intenzita ultrazvukového vlnenia pôsobiaca na tkanivá a mikrobubliny sa vyjadruje takzvaným mechanickým indexom MI. Tento index je definovaný ako pomer vrcholového tlaku (peak rarefactional pressure) v jednotkách *MPa* ku druhej odmocnine nosnej, strednej frekvencie ultrazvukovej sondy (*MHz*) a nadobúda hodnoty z intervalu (0, 2).

Keďže mikrobubliny pri použití vysokého MI zanikajú, je pre ich dlhotrvajúce zachovanie v krvnom obehu potrebné, aby nebola prekročená určitá hodnota MI. Jej veľkosť závisí na použitom preparáte.

Zobrazenie s mikrobublinovými kontrastnými látkami prešlo určitým vývojom. Prvým špecifickým zobrazením bolo použitie „tissue harmonic imaging“, metódy založenej na princípe detekcie násobných harmonických frekvencií, ktoré vznikajú na rozhraní tkanív aj mikrobublín. V dôsledku rušivých odrazov z akustických rozhraní tkanív však tento spôsob zobrazenia poskytoval nekvalitný obraz. Ďalšia metóda zobrazenia, nazývaná SAE – stimulated acoustic emission, využívala vysokoenergetický pulz s vysokým MI, ktorý viedol k deštrukcii mikrobublín. Deštrukcia spôsobila emitovanie krátkeho silného spätného echa, ktoré bolo možné jednoducho zaznamenať.

V súčasnej dobe sa používajú techniky, pri ktorých nedochádza k mechanickej deštrukcii mikrobublín. Tkanivá a mikrobubliny reagujú na ultrazvukové vlnenie rozdielne. Zatiaľ čo tkanivá pod vplyvom tlakových zmien kmitajú len zanedbateľne, bubliny s plynom sú ľahko stlačiteľné a po dopade ultrazvukovej vlny menia svoju veľkosť. Zväčšujú sa pri znížení tlaku („rarefaction phase“) a naopak pri jeho zvýšení („pressure phase“) sa kontrahujú. Bublina sa však ľahšie zväčší ako zmenší a tak dochádza ku asymetrickej oscilácii, ktorá vedie ku vzniku ultrazvukového vlnenia s nelineárnym charakterom. To znamená, že echá, ktoré sa vracajú ku sonde, obsahujú frekvencie a fázy, ktoré vo vysielanej vlne nie sú prítomné. Detekcia tohto nelineárneho vlnenia je kľúčom k oddeleniu ech vznikajúcich na bublinách, od ech vznikajúcich na akustických rozhraniach tkanív [3].

K potlačeniu základnej vysielanej frekvencie sa používa kombinácia postupných ultrazvukových pulzov s odlišnou amplitúdou či opačnou fázou, prípadne kombináciou oboch [4]. Zavedením týchto techník bolo umožnené zobrazenie perfúzie v reálnom čase [5].

1.4.2 Perfúzne zobrazenie

Použitím kontrastných látok v ultrasonografii je teda možné hodnotiť prekrvenie orgánov. Keďže sa perfúzia tkaniva mení v závislosti na mnohých fyziologických a patologických procesoch, jej zobrazenie a kvantifikácia ako objem krvi, ktorý pretečie jednotkou objemu tkaniva za jednotku času, poskytuje informáciu o jeho stave. [3]

Podkladom k odhadu potrebných perfúzných parametrov sú perfúzne krivky, ktoré vyjadrujú zmeny koncentrácie kontrastnej látky vo vybranej oblasti záujmu v závislosti na čase. Odhady týchto parametrov sa získavajú analýzou kriviek [9].

Je všeobecne známe, že onkologické, kardiovaskulárne a zápalové ochorenia sú spojené so zmenou lokálneho a/alebo systémového prekrvenia, ktoré by v prípade reprodukovateľného merania mohlo byť dôležitým biomarkrom pre určovanie diagnózy a hodnotenie aktivity ochorenia [5].

Pre vymedzenie vyššie spomenutej oblasti záujmu, v ktorej je perfúzia hodnotená je dôležitá segmentácia obrazu. Touto problematikou sa zaoberá nasledujúca kapitola.

2 Segmentácia medicínskych obrazových dát

Segmentácia obrazu je základným krokom v algoritme analýzy a spracovania obrazu. S rozvojom digitálnej techniky nachádza segmentácia široké uplatnenie. Príkladom môžu byť priemyselné aplikácie, bezpečnostné systémy, digitalizácia fyzických dokumentov, zobrazovacie systémy v medicíne, či digitálna fotografia.

Segmentácia delí obraz na časti - segmenty, ktoré zodpovedajú konkrétnym objektom v obraze. Vo výsledku má každý obrazový pixel priradený index vyjadrujúci jeho príslušnosť ku konkrétnemu segmentu. Informácia o rozdelení obrazu je ďalej spracovávaná vyššími algoritmami, ktoré sa snažia porozumieť obsahu obrazu. Ich konkrétnou úlohou môže byť detekcia prítomnosti príslušného objektu alebo rozpoznanie a klasifikácia objektov v obraze.

Štruktúra obrazu môže byť veľmi zložitá, hranice objektov sa môžu prekrývať a podobne. V takom prípade je rozlíšenie jednotlivých objektov náročné aj pre trénované ľudské oko, nieto pre počítačový algoritmus [10]. Úspešnosť segmentácie navyše významne ovplyvňuje kvalita vstupných obrazových dát. Tie sú v závislosti na použitej metóde a technológii v procese snímania a digitalizácie deformované rôznym druhom šumu a nehomogenít. Preto je žiaduce, aby samotnej segmentácii predchádzalo vhodné predspracovanie, ktorého cieľom je tieto deformácie potlačiť. Účinnosť reštaurácie obrazu je však v mnohých prípadoch do značnej miery limitovaná. Dôsledkom týchto skutočností sú segmentácia obrazu a s ňou spojený správny popis objektov obrazu radené medzi najzložitejšie úlohy pri spracovaní obrazu.


Vďaka širokému využitiu segmentácie a rozdielnym požiadavkám na jej realizáciu a finálnu podobu v dôsledku rozmanitosti spracovávaných obrazových dát vzniklo veľké množstvo segmentačných algoritmov. Aj napriek tomu, že používané metódy často vznikali nezávisle od seba, existujú spoločné črty, ktoré umožňujú ich klasifikáciu do niekoľkých skupín.

2.1 Segmentácia prahovaním

Metódy založené na prahovaní vychádzajú z predpokladu homogenity oblastí obrazu. Segment by mal byť homogénny z hľadiska vybranej vlastnosti - parametra, ktorým je charakterizovaný. Týmito parametrami môžu byť jas šedotónového obrazu, odrazivosť, farba, textúra. Samotné rozdelenie obrazu na segmenty sa dosahuje stanovením prahu. Pri jednoduchom prahovaní sa jedná o transformáciu vstupného obrazu g na výstupný binárny obraz f s prahom T :

$$f(i, j) = 1 \text{ pre } g(i, j) \geq T, \quad 0 \text{ pre } g(i, j) < T. \quad (2.1) \quad [7]$$

Podobne môže byť definovaných viacej prahov, ktoré delia obraz do viacerých segmentov. Prahy by mali deliť množinu hodnôt daného parametra na disjunktné podmnožiny. Základným problémom tohto typu segmentácie je odhadnutie samotných prahov. Určovanie prahu môže byť napríklad interaktívne so spätnou väzbou. Ďalšou možnosťou je pri určovaní prahu vychádzať z histogramu. Histogram vyjadruje počet pixelov, ktorým je konkrétna hodnota odtieňa šede v obraze zastúpená. Tento spôsob je vhodný pre obrazy s bi-modálnym histogramom, ktorý má dobre separovateľné maximá. Príklad takého histogramu je na Obr. 2.1 (a). Prah je jednoducho stanovený v minime medzi maximami a chyba klasifikácie bude malá. Ak sa ale jedná o prípad ako na Obr. 2.1 (b), keď sa v histograme nevyskytuje minimum, je takáto klasifikácia zaťažená veľkou chybou.



Obr. 2.1 Určovanie prahu z tvaru histogramu: (a) dobre definovateľný prah a (b) obtiažne definovateľný prah [6].

Segmentácia založená na predpoklade homogenity segmentov má prirodzene svoje obmedzenia. Bude zlyhávať v prípade zmien parametrov spôsobených nerovnomerným osvetlením, nedokonalosťami obrazového senzoru alebo vlastnosťami zobrazovaných objektov. Príkladom môže byť prirodzená variabilita vlastností tkaniva vo vnútri orgánu, ktorý by mal byť považovaný za jeden segment. Efektívnosť metódy je vyššia pri použití takzvaného adaptívneho prahovania, ktoré vychádza z hladkej zmeny prahov na celkovej ploche obrazu v závislosti napríklad na vyššie spomínanom nerovnomernom osvetlení.

2.2 Segmentácia založená na hranovej detekcii


Ďalšia skupina metód vychádza z hranovej reprezentácie segmentovaného obrazu. Ich cieľom je poskytnúť hranice segmentov. V ideálnom prípade sú tieto hranice tvorené uzavretými krivkami, ktorých vnútri je požadovaný segment. Hrany sú charakterizované ako miesta obrazu s dostatočne dôležitými a rýchlymi zmenami jasu v malom okolí. Hranu tiež môžeme chápať ako vlastnosť obrazového bodu vyjadrenú ako funkciu obrazu v okolí tohto bodu. Hrana je potom reprezentovaná veľkosťou a smerom [10]. Hranou môže byť okraj väčšieho

objektu v obraze alebo jeho časť, prípadne môže vyjadrovať samostatný objekt ako je čiara alebo bod. Nanešťastie sú dosť často ako hrany detegované aj lokálne zmeny intenzity spôsobené šumom. Tie by mali byť dodatočným spracovaním, ktoré berie do úvahy obsah obrazu odstránené. Globálna hranová detekcia aplikovaná na obraz poskytuje odvodený binárny parametrický obraz – hrubú hranovú reprezentáciu s jednotkami (bielymi pixelmi) na pozíciách, kde bola detegovaná hrana a nulami (čierne pixely) na pozadí, alebo opačne.

Na rozdiel od predchádzajúcej skupiny metód, v tomto prípade na homogenitu oblasti segmentu nie sú kladené žiadne striktné podmienky za predpokladu, že zmeny vo vnútri segmentu sú výrazne slabšie [6].

2.2.1 Hranové detektory

Metódy detegujúce hrany môžu byť založené na vyhodnocovaní rýchlosti zmeny intenzity v okolí pixelu, ktorá je daná absolútnou hodnotou gradientu. Tieto metódy je možné rozdeliť do dvoch skupín, a to na metódy využívajúce prvú a metódy využívajúce druhú deriváciu obrazovej funkcie. Prvá skupina metód porovnáva hodnoty výsledného gradientu s prahom, ktorý určuje, či sa jedná alebo nejedná o hrany. Skupina metód využívajúca druhú deriváciu deteguje hrany v prípade, že priestorová zmena v polarite druhej derivácie je dostatočne významná. Na Obr. 2.2 je schematicky znázornený profil výstupu filtrov prvej a druhej derivácie aplikovaných na hranu a profil samotnej hrany [6].



Obr. 2.2 Schematické profily odoziev operátorov prvej a druhej derivácie na hranu [6].

Detekcia pomocou prvej derivácie

Prvú deriváciu diskrétného obrazu získame ako rozdiel veľkosti jasů okolitých pixelov obrazu, pričom okolité pixely nemusia byť susedné pixely. V najjednoduchšom prípade vypočítame deriváciu zvlášť pre riadky, kde berieme pixely zľava do prava a zvlášť pre stĺpce, kde berieme pixely zhora dole. Výsledný gradient je daný vzťahom:

$$G(i, j) = \sqrt{G_r(i, j)^2 + G_s(i, j)^2}. \quad (2.2) \quad [7]$$

Orientáciu gradientu v obraze vzhľadom k riadkom určíme ako

$$\theta(i, j) = \arctan \frac{G_s(i, j)}{G_r(i, j)}. \quad (2.3) \quad [7]$$

Gradient je tiež možné vypočítať ako 2D konvolúciu impulznej charakteristiky filtra s obrazom. Konkrétne hranové detektory sa líšia maskou operátora, teda impulznou charakteristikou. Maska filtra definuje body, ktoré budú použité pre výpočet gradientu a tiež určuje, aké budú mať váhy. Veľkosť a hodnoty filtra významne ovplyvňujú výsledné vlastnosti hranového detektoru. Citlivosť na šum výrazne ovplyvňuje veľkosť masiek, a preto sa používajú aj masky väčšie ako 3x3.

V nasledujúcej tabuľke sú uvedené impulzné charakteristiky významných filtrov.

Tab. 2.1 Impulzné charakteristiky významných filtrov

Operátor	Riadkový gradient	Stĺpcový gradient
Prostá diferencia	$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & -1 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
Separovaná prostá diferencia	$\begin{bmatrix} 0 & 0 & 0 \\ 1 & 0 & -1 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix}$
Robertsov	$\begin{bmatrix} 0 & 0 & -1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
Prewittovej	$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$
Sobelov	$\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$
Kirschov	$\begin{bmatrix} 3 & 3 & -5 \\ 3 & 0 & -5 \\ 3 & 3 & -5 \end{bmatrix}$	$\begin{bmatrix} -5 & -5 & -5 \\ 3 & 0 & 3 \\ 3 & 3 & 3 \end{bmatrix}$

Nevýhodou uvedených gradientných operátorov, ako už bolo spomenuté, je citlivosť na šum a veľká závislosť na veľkosti objektov v obraze [10].

Detekcia pomocou druhej derivácie

Pri detektoroch založených na druhej derivácii sa najčastejšie používa detekcia priechodu nulou, pretože ako vyplýva z Obr. 2.2 je omnoho jednoduchšia ako hľadanie extrému.

Jedným z operátorov aproximujúcich druhú deriváciu je Laplacián. Je invariantný voči rotácii vďaka rovnakým vlastnostiam v každom smere.

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Obr. 2.3 Konvolučné masky normalizovaného Laplaciánu so 4-okolím a 8-okolím [10].

Nevýhodou Laplaciánu je jeho veľká citlivosť na šum a dvojité odozvy na niektoré hrany v obraze [10].

Lepšie výsledky by Laplacián dosiahol, ak by bol obraz predspracovaný vyhladzovacím operátorom s Gaussovou maskou. Linearita oboch po sebe idúcich operátorov umožňuje ich zlúčenie a tým zjednodušenie operácie na jednu konvolúciu. Aproximácia tohto filtra maskou veľkosti 5x5 je uvedená na Obr. 2.4 [6].

$$\begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 16 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$

Obr. 2.4 Konvolučná maska filtra Laplacian of Gaussian s rozmermi 5x5 [6].

Ďalšími nevýhodami metód druhej derivácie detegujúcich priechod nulou je príliš veľké vyhladenie obrazu, strata ostrých rohov a sklon k vytváraniu uzavretej slučky hrán.


2.2.2 Houghova transformácia

Významnou segmentačnou metódou založenou na detekcii hrán je Houghova transformácia. Segmentácia je v tomto prípade postavená na transformácii karteziánskeho súradnicového systému na systém polárny. Jej veľkou výhodou je malá citlivosť na šum a porušené hranice. Pri tejto metóde je však potrebné poznať analytický popis hľadaného objektu. V obraze môžu byť teda detegované známe jednoduché tvary ako sú priamka, kružnica, elipsa, trojuholník a podobne.

Priamka je parametricky vyjadrená v tvare

$$\rho = x \cdot \cos\theta + y \cdot \sin\theta, \quad (2.4) \quad [10]$$

kde ρ je normalizovaná vzdialenosť priamky od počiatku a θ je uhol vzhľadom k ose x . Každý bod obrazu je v parametrickom priestore prezentovaný krivkami. Ak sa jedná o body ležiace na jednej priamke, znamená to, že v parametrickom priestore sa pretnú práve v bode reprezentujúcom parametre hľadanej priamky (krivky). Ukážka Houghovej transformácie je na Obr. 2.5.



Obr. 2.5 Houghova transformácia priamky.

Metódu je možné použiť aj na detekciu ľubovoľných tvarov, keď jednoduchý analytický popis objektu nie je možný. V takom prípade sa vychádza zo zovšeobecnenej Houghovej transformácie [10].

2.3 Regiónovo orientovaná segmentácia

Segmentácia založená na predstave regiónov – oblastí obrazu s určitou spoločnou vlastnosťou, tiež využíva koncept homogenity, avšak v tomto prípade môže byť aplikovaný lokálnejšie a tým poskytuje väčšiu flexibilitu v definícii segmentu. Spoločnou vlastnosťou – parametrom môže byť v najjednoduchšom prípade intenzita pixelu, ďalej farba, textúra a podobne. Namiesto hraníc segmentov sú detegované priamo oblasti v obraze. Metódy sa vyznačujú vyššou efektivitou pre zašumené obrazové dáta.

2.3.1 Segmentácia narastaním oblasti

Segmentácia narastaním oblasti je z metód regiónovo orientovanej segmentácie konceptuálne najjednoduchším a pravdepodobne aj historicky najstarším postupom v segmentácii. Princíp je celkom jednoduchý: v každom potenciálnom regióne je určené semienko, ktoré do daného regiónu patrí a má v určitom definovanom zmysle vlastnosti pre neho typické, obvykle dané parametrom p ako je intenzita, stredná hodnota, rozptyl a podobne. Ďalšie okolité pixely budú

potom do regiónu pripojené, ak splnia určité kritérium homogenity. Určovanie semienok je samostatnou úlohou, ktorá je často riešená interaktívne, náhodným výberom alebo určitou predbežnou analýzou. Posledná z možností sa používa pri plne automatických segmentačných algoritmoch. V najjednoduchšom prípade vyzerá iteračný proces nasledovne: pre každý pixel daného regiónu (spočiatku semienko) sa overuje jeho okolie a hodnoty parametrov kandidátov p_j sa porovnávajú s hodnotami parametra semienka p_s . Ak je podmienka

$$|p_s - p_j| \leq T \quad (2.5) \quad [6]$$

splnená pre zodpovedajúci pixel okolia, pixel sa priradí ako nový člen regiónu. V opačnom prípade sa označí za neakceptovateľný. Algoritmus končí v situácii, keď žiadny zo susedných pixelov regiónu nespĺňa danú podmienku alebo už sú všetky súčasťou iného regiónu. Je zrejmé, že ak sa rozsahy parametrov susedných segmentov prekrývajú, výsledok segmentácie bude závislý na poradí, v akom sú oblasti spracované.

Situácia sa výrazne zmení, keď sa podmienka upraví na

$$|p_i - p_j| \leq T, \quad (2.6) \quad [6]$$

kde p_i je hodnota parametra už priradeného pixelu, ktorého okolie sa aktuálne testuje. Keďže sa referenčná hodnota p_i v tomto prípade môže pozvoľna meniť, metóda a je schopná sledovať postupný nárast a pokles hodnoty parametra v regióne a stáva sa robustnejšou. Nárast alebo pokles je v jednotlivých smeroch zastavený prudkou zmenou vyjadrujúcou vysoký gradient, ktorý môže byť spôsobený okrajom regiónu. Týmto spôsobom sa predstava homogenity zovšeobecňuje v zmysle akceptovania regiónov s pomaly a hladko sa meniacim parametrom (napríklad nerovnomerne osvetlený povrch), čo môže v určitých prípadoch značne zdokonaľiť segmentáciu. Na druhej strane však tvar a veľkosť výsledného segmentu potom záleží nie len na pozícii semienka, ale tiež na poradí, v akom sú pixely spracované. Hrana, ktorá je neprekonateľná postupom algoritmu z jednej strany, sa môže stať dostatočne slabou postupom z inej strany, ktorý vedie k inej hodnote p_i , a opačne [6].

2.3.2 Segmentácia zlučovaním oblastí

Segmentácia zlučovaním oblastí začína s elementárnymi oblastami, ktoré je možné považovať za homogénne. Najčastejšie sú týmito oblastami prirodzene jednotlivé pixely. Dve susediace oblasti môžu byť zlúčené v prípade splnenia určitého kritéria homogenity. Proces zlučovania potom pokračuje, až kým všetky oblasti nie sú obklopené výhradne областami s výrazne odlišným kritériom, a tým pádom žiadne ďalšie zlučovanie nie je možné.

Kritérium homogenity môže byť formulované staticky – nemenným rozsahom určitého parametra všetkých pixelov oblasti, ktorá má vzniknúť spojením,

$$p_{i,m,n} \in \langle p_0 - \Delta p, p_0 + \Delta p \rangle, \quad (2.7) \quad [6]$$

kde p_0 je hodnota (alebo priemerná hodnota) parametra počiatkovej časti oblasti so zvoleným intervalom voľnosti Δp . Flexibilnejšou definíciou homogenity je dynamická definícia založená na určitom spôsobe definovanej podobnosti oblastí, ktoré majú byť zlúčené. Príkladom môže byť definovanie rozdielu priemerných hodnôt parametra daného kritéria oboch oblastí. Keďže je priemerná hodnota ovplyvnená postupne pridávaným okolím, jej hodnota sa mení v priebehu procesu, a to môže umožniť zlúčenie výraznejšie odlišných oblastí. Vo výsledku je teda možné dosiahnuť v porovnaní so statickým kritériom väčšie a zmysluplnejšie oblasti [6].


2.3.3 Segmentácia delením a zlučovaním oblastí

Delenie oblastí je v určitom zmysle komplementárnym postupom k ich spájaniu. Základnou myšlienkou delenia je rozdeliť oblasti, ktoré nie sú z hľadiska vybraného kritéria jednotné (homogénne) na podoblasti. Postup je opakovaný so stále menšími regiónmi až kým každý z nich nie je homogénny. Samotné delenie však neposkytuje uspokojivú segmentáciu, pretože niektoré susediace regióny môžu zostať rozdelené aj napriek tomu, že spĺňajú kritérium pre zlúčenie. Z tohto dôvodu sa používa kombinácia obidvoch postupov. Je vhodné poznamenať, že výsledky segmentácie zlučovaním oblastí a výsledky segmentácie delením a zlučovaním oblastí sa môžu výrazne líšiť.

Najmenej komplikovaný spôsob delenia pozostáva z rozštvrtienia obrazu, ktoré je opakované na toľkých úrovniach, koľko je potrebné pre dosiahnutie homogenity vo vnútri regiónov. Stupeň homogenity je vyhodnotený v každej úrovni. Ak je nedostatočný, región je rozdelený na štvrtiny a tým vytvára novú úroveň. Oblasť po splnení kritéria homogenity prirodzene nepodlieha ďalšiemu deleniu. Týmto spôsobom je dosiahnutá hierarchická reprezentácia obrazu štvorstromom (quadtree) – obraz môže byť popísaný stromovým grafom. Najvyšší uzol (koreň) zodpovedá celému obrazu, uzol bezprostredne nižšej úrovne jeho štvrtinovým oblastiam, atď. Každý uzol teda reprezentuje časť obrazu, ktorého veľkosť a pozícia vyplývajú z pozície uzlu v grafe. Uzol je označený priemernou hodnotou parametra v oblasti, ktorú reprezentuje. Z tohto materského uzla vedú v prípade nesplnenia kritéria homogenity ďalšie štyri vetvy do ďalšej dcérskej úrovne.

Po skončení procesu delenia by mal byť jeho výstup z dôvodov spomenutých na začiatku tejto podkapitoly podrobený algoritmu zlučovania oblastí uvedeného v predchádzajúcej kapitole 2.3.2.


Delenie oblastí teda poskytuje súbor vhodných počiatkových oblastí pre algoritmus zlučovania. Segmentácia delením a zlučovaním oblastí je pomerne robustná, hoci má prirodzene tendenciu k vytváraniu „schodovitých“ oblastí. Príklad výsledku tejto metódy segmentácie je spolu so zodpovedajúcim stromovým grafom uvedený na Obr. 2.6. [6].



Obr. 2.6 Segmentácia delením a zlučovaním: (a) pôvodný obraz, (b) oblasti po delení, (c) výsledný obraz, (d) stromový graf deleného obrazu [6].

2.3.4 Segmentácia algoritmom rozvodia


Metóda segmentácie algoritmom rozvodia považuje za segmenty oblasti, ktoré sú vytvorené definovaním okolia každého lokálneho minima intenzity jasu alebo iného parametra. Názov metódy pochádza z podobnosti povrchovej reprezentácie intenzity obrazu s topografickým modelom nadmorskej výšky. Vid' Obr. 2.7.



Obr. 2.7 Rozdielna reprezentácia obrazu: šedotónový obraz (vľavo), povrchová reprezentácia intenzity (vpravo) [6].

V skúmanom obraze predstavujú tmavé oblasti s nízkou intenzitou údolia a svetlé odtiene šedi s vysokou intenzitou zasa kopce a pohoria. Na takomto povrchu je možné rozoznať určité lokálne minimá, ktoré sú následne špecificky označené za zástupcov

individuálnych segmentov. Oblasť patriaca k minimu je definovaná ako množina bodov, z ktorých by kvapka vody najstrmšou možnou cestou stiekla do daného minima. Takáto oblasť sa nazýva povodím a hranica medzi dvoma povodiami sa nazýva rozvodím. Metóda predpokladá, že rôzne povodia zodpovedajú zmysluplným oblastiam obrazu. To, či je predpoklad správny alebo nie, závisí na charaktere obrazu a na zobrazovanom objekte alebo scéne. Metóda segmentácie rozvodím je často aplikovaná na parametrický obraz získaný aplikovaním gradientných operátorov. Je zrejmé, že v takom prípade budú línie hrebeňov tvoriace rozvodia zodpovedať okrajom objektov. Výsledok môže byť podobný segmentácii založenej na prahovanej hranovej detekcii. Výhodou tejto metódy je však podstatne väčšia robustnosť vzhľadom na šum. Vyššie spomenutá definícia platí pre spojitý povrch kde sú povodia určené unikátne. V diskrétnom prostredí cesta vodného spádu nemusí byť pri rovnakých hodnotách susediacich pixelov unikátna. Navyše, rozpoznanie cesty spádu a určovanie, ku ktorému minimu každý obrazový pixel patrí, je výpočtovo veľmi náročné. Z tohto dôvodu bola definovaná ekvivalentná definícia, ktorá je založená na pomyselnom zaplavovaní povrchu. Ak sa v povrchu v mieste každého lokálneho minima vytvorí malá diera a celý povrch sa pomaly ponára do vody, voda postupne zaplní všetky povodia. Aby povodia zostali oddelené aj keď voda dosiahne najvyššie úrovne, na líniách hrebeňov musia byť postavené zvislé hrádze. Tieto hrádze predstavujú hranice segmentov. Príklad segmentácie touto metódou je uvedený na Obr. 2.8.



Obr. 2.8 Originálny obraz (a), výsledok segmentácie algoritmom rozvodia (b).

2.4 Segmentácia pomocou pružných a aktívnych kontúr

Segmentácia pomocou pružných a aktívnych kontúr (snakes, active contours) je založená na postupnom tvarovaní vopred zadaných kontúr až ku hrane objektu. Model aktívnej kontúry je riadená uzavretá kontúra, deformovaná vplyvom takzvaných vnútorných, obrazových a vonkajších síl. Vnútorné sily zabezpečujú hladkosť priebehov, obrazové sily smerujú tvarovanie kontúry ku hrane objektu a vonkajšie sily sú výsledkom počiatočného umiestnenia kontúr [7]. Počiatočné kontúry môžu byť vyznačené interaktívne alebo sa môže vychádzať

zo znalosti približného tvaru segmentovanej oblasti. Model sa na základe týchto síl vyvíja do doby, kým dosiahne rovnovážny stav.

Úspech metódy môže byť výrazne ovplyvnený výberom počiatočných kontúr [6]. Pri návrhu by sa preto mali brať do úvahy vlastnosti obrazu, ktorým je možné prispôbiť napríklad stupeň flexibility krivky. Metóda sa často radí medzi pokročilé metódy detekcie hrán. Existuje však množstvo navrhnutých postup merania vyššie uvedených síl [7]. Na základe týchto postupov je možné metódy deliť na metódy s prístupom hranovej detekcie, regiónovo orientované metódy a hybridné metódy modelov aktívnych kontúr [18].


Výhodou metódy je výrazná robustnosť voči šumu, vďaka ktorej sa metóda často používa na segmentáciu medicínskych ultrazvukových obrazov.

2.5 Využitie matematickej morfológie v segmentácii

Aplikácia matematickej morfológie je v spracovaní obrazu veľmi široká. Používa sa na predspracovanie obrazu, finálne úpravy obrazu, detekciu hrán a môže byť použitá aj pre samotnú segmentáciu. Matematická morfológia môže pracovať s binárnymi aj šedotónovými obrazmi. V tejto práci je však využitá iba na finálne úpravy segmentov reprezentovaných binárnym obrazom.

Matematickú morfológiu je možné definovať ako matematický nástroj pre extrakciu požadovaných tvarov. Princíp matematickej morfológie spočíva v nelineárnych operáciách v obraze, kde sa využíva popis obrazu pomocou terminológie teórie množín.


Definičným oborom pre popis dvojrozmerných útvarov je dvojrozmerný euklidovský priestor E^2 a systém jeho podmnožín. Objekt v binárnom obraze je popísaný ako 2D bodová množina. Množina X bude obsahovať body s hodnotou 1 predstavujúce body objektu a doplnková množina X^c s hodnotou 0 predstavujúce body pozadia. Takéto vyjadrenie je uvedené na Obr. 2.9.



$$X = \{(1,0), (1,1), (1,2), (0,3), (0,4), (2,3), (2,4)\}$$

Obr. 2.9 Objekt v binárnom obraze je popísaný ako 2D bodová množina [16].

Morfologická transformácia Y je relácia medzi množinou obrazu X a štrukturálnym elementom B . Štrukturálny element je systematicky posúvaný po X a výsledok transformácie je postupne zapisovaný do výsledného binárneho obrazu.




Obr. 2.10 Typické štrukturálne elementy [16].

Základnými operáciami binárnej morfológie sú: dilatácia, erózia, otvorenie, uzatvorenie.

Dilatácia je relácia, ktorá skladá body dvoch množín pomocou vektorového súčtu. Je definovaná takto:

$$X \oplus B = \{p \in \varepsilon^2, p = x + b, x \in X, b \in B\}. \quad (2.8) \quad [16]$$

Dilatácia zväčšuje objekt a používa sa na zaplnenie malých dier a úzkych zálivov [17]. Príklad dilatácie je uvedený na Obr. 2.11.



$$X = \{(1,0), (1,1), (1,2), (0,3), (1,3), (2,3), (3,3)\}, \quad B = \{(0,0), (0,1)\}$$


$$X \oplus B = \{(1,0), (1,1), (1,2), (0,3), (1,3), (2,3), (3,3), (0,4), (1,4), (2,4), (3,4)\}$$

Obr. 2.11 Príklad dilatácie [16].

Erózia zjednodušuje štruktúru objektu a stenčuje objekty, pričom príliš tenké a malé sa stratia [17]. Odpočítaním originálneho obrazu od dilatovaného je možné detegovať hrany. Definícia erózie:

$$X \ominus B = \{p \in \varepsilon^2, p + b \in X, \forall b \in B\}. \quad (2.9) \quad [16]$$

Príklad erózie je uvedený na Obr. 2.12.



$$X = \{(1,0), (1,1), (1,2), (0,3), (1,3), (2,3), (3,3), (1,4)\}, \quad B = \{(0,0), (0,1)\}$$

$$X \ominus B = \{(1,0), (1,1), (1,2), (1,3)\}$$

Obr. 2.12 Príklad erózie [16].

Dilatácia a erózia nie sú navzájom inverznými transformáciami. Ich kombináciou vznikajú ďalšie dôležité transformácie ako otvorenie a uzatvorenie.

Otvorenie je morfológická transformácia, ktorá je získaná dilatáciou erodovaného obrazu. Otvorenie množiny X štruktúrnym elementom B sa zapisuje nasledovne:

$$X \circ B = (X \ominus B) \oplus B \quad (2.10) \quad [16]$$

Otvorenie zjednodušuje štruktúru objektov a oddeľuje objekty spojené úzkymi čiarami [16].

Uzatvorenie je morfológická transformácia, ktorá je získaná eróziou dilatovaného obrazu. Uzatvorenie množiny X štruktúrnym elementom B sa zapisuje takto:

$$X \bullet B = (X \oplus B) \ominus B \quad (2.10) \quad [16]$$

Uzatvorenie zaplňa malé diery a zálivy, spája objekty, ktoré sú dosť blízko seba a vyhladzuje tvar objektov [16].

2.6 Metódy segmentácie kontrastných ultrazvukových sekvencií

Z dôvodu prítomnosti šumu typu speckle a artefaktov spôsobených atenuáciou je otázka spoľahlivosti segmentácie obyčajných ultrasonografických dát zložitejšia ako pri dátach z iných zobrazovacích systémov. Štandardné prístupy segmentácie založené na prahovaní alebo hranovej detekcii často zlyhávajú, pretože kontúry nájdené týmito metódami sú veľmi hrubé, nepresné a väčšinou nie sú uzatvorené. Pre riešenie tejto úlohy preto musia byť použité sofistikovanejšie metódy. Sľubnými a v bežnej praxi používanými metódami sú vyššie spomenuté metódy aktívnych kontúr. Množstvo metód používaných na segmentáciu ultrazvukových sekvencií kombinuje viacero segmentačných prístupov, z ktorých je možné

spomenúť štatistické metódy a metódy využívajúce neurónové siete, pre ktoré sú potrebné trénovacie dáta s manuálne vymedzenými hranicami segmentov [11].

V prípade kontrastných ultrazvukových sekvencií je však situácia iná, pretože pre vyhodnotenie priebehu koncentrácie z nasnímaných sekvencií nie je anatomická presnosť sledovaných štruktúr až taká podstatná a navyše je použitím kontrastnej látky zlepšený pomer signál/šum. Je možné predpokladať, že základné metódy segmentácie budú dostačujúce pre približné vymedzenie oblasti a vďaka zlepšeniu kontrastu v sekvenciách nebudú často zlyhávať. Základné metódy sú oproti tým sofistikovanejším výpočtovo a časovo menej náročné, čo je pre segmentáciu sekvencií výhodné. Z týchto predpokladov sa v práci vychádzalo aj pri výbere realizovaných metód, ktoré sú však obmedzené len na spracovanie obrazových dát.

Segmentácia môže byť realizovaná bez prihliadania na časový vývoj a súvislosť medzi jednotlivými snímkami sekvencie. V takom prípade sa snímky segmentujú nezávisle na sebe. Je však výhodné a pri snímaní statickej scény možné vzhľadom k nutnosti zadávania semienka alebo východiskovej oblasti použiť pre segmentáciu ďalšieho snímku sekvencie informáciu zo snímku predošlého. Takto by bolo možné obmedziť manuálne zadávanie semienok len na prvý zo snímkov z celej sekvencie.

V prípade dynamickej scény by bolo možné segmentáciu základnými metódami použiť pre zarovnanie snímkov sekvencie v závislosti na oblasti záujmu do jednej línie, v ktorej by sa oblasti záujmu prekrývali.


3 Implementácia vybraných segmentačných metód v programovom prostredí Matlab

V tejto kapitole sú popísané algoritmy zvolených segmentačných metód, ktoré boli realizované v programovom prostredí Matlab vo verzii R2012b 8.0.0.783. Pre jednoduché užívateľské ovládanie a testovanie navrhnutých algoritmov bolo vytvorené grafické užívateľské rozhranie (GUI), v ktorom sú integrované obidve skupiny metód. Pre zvýšenie účinnosti segmentácie pomocou použitých metód je program doplnený o voliteľné predspracovanie a dodatočné úpravy.

Umelo vytvorené testovacie obrazové dáta, ktorých príklad je uvedený na Obr. 3.1 boli vytvorené v programe Maľovanie, ktorý je súčasťou operačného systému MS Windows 7. Tieto dáta boli následne poškodené multiplikatívnym šumom typu speckle, ktorý je charakteristický pre ultrasonografické obrazy. Pre tento účel bola použitá funkcia `imnoise(I, 'speckle', v)`, ktorá je súčasťou image processing toolboxu programového prostredia Matlab, kde prvým vstupom `I` je znehodnocovaný obraz, druhý vstup charakterizuje druh pridávaného šumu. V tomto prípade sa jedná o šum typu 'speckle'. Tretí vstup `v` udáva rozptyl rovnomerne rozloženého šumu. Tento šum je charakterizovaný rovnicou 3.1.


$$J = I + n * I, \quad (3.1)$$

kde n je rovnomerne rozložený náhodný šum so strednou hodnotou 0 a rozptylom v , I predstavuje vstupný obraz a J obraz výstupný. Testovacie obrazové dáta boli vytvorené s hodnotami rozptylu šumu: $v_1 = 0,1$ a $v_2 = 0,2$. Obraz je zložený zo štyroch kruhov. Ich rozdielne odtiene šedi simulujú rôzny kontrast v obraze a preto sa k ich segmentácii pristupuje jednotlivo, ako keby to boli štyri rôzne obrazy.



Obr. 3.1 Umelo vytvorené obrazové dáta s rozptylom šumu $v_1 = 0,1$.


Fantómové dáta boli získane ultrazvukovým systémom GE VingMed System FiVe pomocou 2,5 MHz sondy s využitím harmonického zobrazenia na modeli tkaniva, ktoré je reprezentované pomocou dialyzačného filtra. V hrubších hadiciach sa ďalej meria arteriálny vstup do systému (AIF) a venózný výstup (VOF). Vyhodnocuje sa priebeh koncentrácie kontrastnej látky v jednotlivých častiach. Rovina snímania je naznačená na Obr. 3.2.



Obr. 3.2 Schéma fantómu použitého na získanie testovacích dát.

Ako kontrastná látka bola použitá SonoVue, čo je látka obsahujúca veľké množstvo mikrobublín plynu SF₆. Koncentrácia kontrastnej látky je odvodená zo signálu na druhej harmonickej frekvencii.

Zo sekvencií meraných na tomto fantóme boli vybrané tri dvojice obrazov. Každá z dvojíc zachytáva inú fázu prietoku kontrastnej látky fantómom. Dáta boli kvôli upraveniu rozsahu dynamiky spracované logaritmickou kompresiou. Ukážka jedného z obrazov je na Obr. 3.3.



Obr. 3.3 Fantómové dáta – fáza prietoku kontrastnej látky cez dialyzačný filter (ROI).

3.1 Predspracovanie obrazu

Voliteľné predspracovanie ponúka možnosť aplikovať na segmentovaný obraz mediánový filter s rôznou veľkosťou okna. Mediánová filtácia je široko používanou a veľmi efektívnou metódou pre potlačenie impulzného šumu. Existuje množstvo uznávaných techník, ktoré môžu byť aplikované pre potlačenie šumu typu speckle. Medián a Wienerov filter sú pravdepodobne tými najznámejšími [14]. Množstvo publikácií sa zaoberá rôzne odvodenými mediánovými filtermi ako sú adaptívne váhovaný mediánový filter [15], smerový mediánový filter [12], prípadne kombináciami mediánového filtra s inými a podobne. Rozoberať metódy pre potlačenie specklov by však bolo nad rámec tejto práce, a preto bude dostačujúci stručný popis princípu a vlastností v práci použitého základného mediánového filtra.

Mediánový filter patrí medzi nelineárne filtre a na rozdiel od priemerujúceho filtra zachováva hrany.

Princíp filtra je jednoduchý: okno filtra postupne prechádza každým obrazovým pixelom a zoraduje všetky hodnoty v okne od najmenšej po najväčšiu, pričom aktuálnu centrálnu hodnotu nahradí tou, ktorá je medzi maximom a minimom – teda mediánom. Princíp je zrejmý z Obr. 3.4.

$$\begin{bmatrix} 4 & 3 & 6 \\ 3 & 25 & 0 \\ 8 & 1 & 11 \end{bmatrix} \Rightarrow 0 \ 1 \ 3 \ 3 \ [4] \ 6 \ 8 \ 11 \ 25$$

Obr. 3.4 Princíp mediánového filtra s veľkosťou okna 3x3. (hodnota v zátvorkách vpravo je mediánom hodnôt v okne filtra).

V programe je filtrácia realizovaná vstavanou funkciou Matlabu `medfilt2(A, [m n])`, kde A predstavuje vstupný obraz a $[m \ n]$ sú rozmery okna filtra. V GUI sú rozmery okna obmedzené na štvorcový tvar, teda $m = n$ a jeho veľkosť na nepárne čísla od 3 do 15.

3.2 Segmentácia založená na hranovej detekcii

Realizovaná segmentačná metóda je založená na detekcii hrán pomocou hranových detektorov a princíp algoritmu vychádza z kapitoly 2.2.1. Na výber je sedem lokálnych operátorov: Robertsov, Prewittovej, Sobelov, Kirschov, Laplacian, Laplacian of Gaussian s veľkosťou masky 5x5 a Laplacian of Gaussian s veľkosťou masky 9x9. Masky prvých štyroch operátorov zodpovedajú tým, ktoré sú uvedené v Tab. 2.1. Masky ďalších dvoch operátorov zodpovedajú maskám uvedeným na Obr. 2.3 vľavo a na Obr. 2.4. Vzhľad poslednej masky je k dispozícii v zdrojovom kóde programu.

V prvom kroku sa pomocou vstavanej funkcie `conv2(A,B,'same')` vypočíta 2D konvolúcia masky filtra B so vstupným obrazom A . Výstupom operácie je gradientný obraz.

Tretí vstup 'same' značí, že výstupný obraz bude centrálnou časťou výslednej matice danej konvolúciou s rovnakou veľkosťou, akú má vstupný obraz. V prípade operátorov vychádzajúcich z prvej derivácie je konvolúcia počítaná zvlášť pre riadky a zvlášť pre stĺpce so zodpovedajúcim variantom masky. V prípade zvyšných troch operátorov je počítaná len jedna konvolúcia a jej výstup je prevedený na jeho absolútnu hodnotu.

Následne sú hodnoty všetkých pixelov získaného parametrického obrazu porovnané s prahom, ktorý je zadaný užívateľom. V prípade hodnoty väčšej ako prah je v pomocnej matici núl rovnakej veľkosti ako pôvodný obraz na zodpovedajúcej pozícii prepísaná nula na jednotku, čím vzniká binárny obraz vyjadrujúci hrubú hranovú reprezentáciu. Pri použití prvých štyroch operátorov je pred krokom prahovania počítaný výsledný gradient podľa rovnice 2.2. Až následne je z neho získaný binárny obraz vyššie popísaným prahovaním. Veľkosť prahu je pre uľahčenie výberu normalizovaná na interval od 0 do 10 z dôvodu rôznych rozsahov hodnôt v matici parametrického obrazu po výpočte konvolúcie.

3.3 Segmentácia založená na narastaní oblasti


Narastanie oblasti je realizované tromi podobnými algoritmami, ktoré sa líšia v kritériu pre priradenie pixelu do regiónu, ale principiálne vychádzajú z kapitoly 2.3.1. V prvom prípade je kritérium popísané rovnicou 2.5, v druhom prípade rovnicou 2.6. Tretí algoritmus porovnáva hodnotu intenzity okolitých pixelov regiónu s priemernou hodnotou intenzity pixelov aktuálne patriacich do regiónu. Rovnicami sa dá kritérium popísať takto:

$$|p_p - p_j| \leq T, \quad (3.2)$$

kde

$$p_p = \frac{1}{n} \sum_{i=1}^n p_i. \quad (3.3)$$

Každý z algoritmov je realizovaný pre overovanie štvor-okolia aj osem-okolia.



Obr. 3.5 Štvor-okolie a osem-okolie pixelu [6].

Vo všeobecnosti je možné algoritmus popísať v niekoľkých krokoch nasledovne:

1. Na začiatku algoritmu je volaná funkcia, prostredníctvom ktorej užívateľ myšou označí semienko/východiskovú oblasť (v závislosti na algoritme). Výstupom tejto funkcie sú súradnice semienka/pixelov východiskovej oblasti.

2. Vytvorenie matice núl g slúžiacej pre výstupný obraz. Počas bežania algoritmu sa v tejto matici postupne nahrádzajú nuly jednotkami a tým vzniká výsledný binárny obraz segmentu a pozadia.
3. Nahradenie nuly na pozícii semienka/pixelov východiskovej oblasti v matici g jednotkou.
4. Vytvorenie prázdneho bunkového poľa veľkosti $1 \times n$, kde n je počet iteračných cyklov zadany užívateľom pred spustením algoritmu. Bunkové pole slúži na ukladanie matíc výsledku v každom cykle nadradeného *for* cyklu.
5. Začiatok nadradeného *for* cyklu. V druhom a ďalšom cykle sa overuje, či je rozdiel výsledku aktuálne posledného a predposledného cyklu nulový. Ak je rozdiel nulový, znamená to, že v poslednom cykle nebol do oblasti pridaný žiadny pixel z testovaného okolia a algoritmus sa ukončí. Ak rozdiel nulový nie je, cyklus beží až do dosiahnutia počtu iterácií zadaného užívateľom.
6. V každom cykle je pomocou vlastnej funkcie *obrysy* získaný obrys aktuálneho segmentu a namiesto okolia každého pixelu oblasti sa overuje len okolie okrajových pixelov. Program by bol bez tohto kroku pomalší a výpočtovo náročnejší.
7. Získanie súradníc pixelov obrysu vstavanou funkciou *find*.
8. V poslednom kroku algoritmu je overované okolie každého pixelu obrysu aktuálnej oblasti. Ak testovaný pixel spĺňa kritérium daného algoritmu, v matici g je na jeho pozícii nula nahradená jednotkou. Tento krok je realizovaný *for* cyklom, ktorého počet opakovaní závisí na počte pixelov aktuálneho obrysu oblasti. Po ukončení tohto cyklu sa jeho výstup ukladá ako matica do pripraveného bunkového poľa a algoritmus sa vracia na krok č. 6.

Oblasť, ktorá bude vo výsledku hľadaným segmentom, týmto spôsobom postupne narastá, až kým nie sú priradené všetky pixely, ktoré spĺňajú dané kritérium alebo kým neprebehne obmedzený počet cyklov.

Pre výber semienok v prvých dvoch algoritmoch je použitá funkcia *getpts*. Počet semienok nie je obmedzený, algoritmy sú však programované pre segmentáciu, ktorej výstupom je jeden segment a pozadie, a preto nie je vhodné semienka umiestňovať do rôznych oblastí s rôznymi odtieňmi šedi. Ak sa tak stane, je pravdepodobné, že algoritmus „vytečie“ mimo požadovanú oblasť. V treťom algoritme je pre vyznačenie východiskovej oblasti použitá vstavaná funkcia *roipoly*. Prvý algoritmus v kroku č. 8 porovnáva hodnoty jasů pixelov okolia regiónu s hodnotou jasů semienka, druhý algoritmus porovnáva hodnoty jasů pixelov okolia regiónu s hodnotou jasů aktuálneho okrajového pixelu a tretí algoritmus, ako už bolo spomenuté v úvode tejto podkapitoly, porovnáva hodnoty jasů pixelov okolia regiónu s priemernou hodnotou jasů pixelov regiónu.

3.4 Finálne úpravy segmentácie

Voliteľné dodatočné úpravy výstupov obidvoch skupín metód, ako už bolo spomenuté v kapitole 2.5, principiálne vychádzajú z matematickej morfológie.

Pre úpravu hrubej hranovej reprezentácie je k dispozícii spolu sedem možností: spájanie hrán, stenčovanie hrán, erózia, dilatácia, otvorenie a uzatvorenie kombináciou dilatácie a erózie a získanie segmentov vyplnením uzatvorených hrán.

Princíp spájania hrán je založený na podmiennej dilatácii postupným aplikovaním masiek, ktoré sú uvedené na Obr 3.6.

$$\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 1 & 0 & 0 \end{bmatrix} \quad \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

Obr. 3.6 Tri z dvanástich masiek pre podmiennej dilatáciu. [6].

Z každej masky na Obr. 3.5 sú rotáciou odvodené ešte ďalšie tri. Spolu ich je teda dvanásť a každá z nich reprezentuje rôzne smery hrán v obraze. Každá z masiek je postupne posúvaná obrazom. Ak sú pixely obrazu pod aktuálnou maskou rovné hodnotám masky, na pozícii centrálného pixelu je v obraze nahradená nula jednotkou a tým sú nesúvislé hrany spojené.

Stenčovanie je založené na podobnom princípe. Jedná sa však o podmiennej eróziu a na obraz je aplikovaných osem masiek, z ktorých dve sú uvedené na Obr. 3.7.

$$\begin{bmatrix} 1 & x & 0 \\ 1 & 1 & 0 \\ x & 0 & 0 \end{bmatrix} \quad \begin{bmatrix} x & 1 & x \\ 1 & 1 & x \\ x & x & 0 \end{bmatrix}$$

Obr. 3.7 Dve z ôsmich masiek pre podmiennej eróziu. [6].

V tomto prípade je na pozícii centrálného pixelu nahradená jednotka nulou v prípade, keď sú pixely pod jednotkami masky rovné jednej a pixely pod nulami masky rovné nule. Pixely pod x masky môžu mať ľubovoľnú hodnotu.

Erózia a dilatácia vychádzajú z princípu morfológických operácií použitím štruktúrálnych elementov rozmeru 3x3.

Pre vyplnenie oblastí ohraničenej súvislými hranami je použitá vstavaná funkcia `imfill(A, 'holes')`, kde A je vstupným binárnym obrazom a vstup `'holes'` definuje konkrétnu podobu danej funkcie.

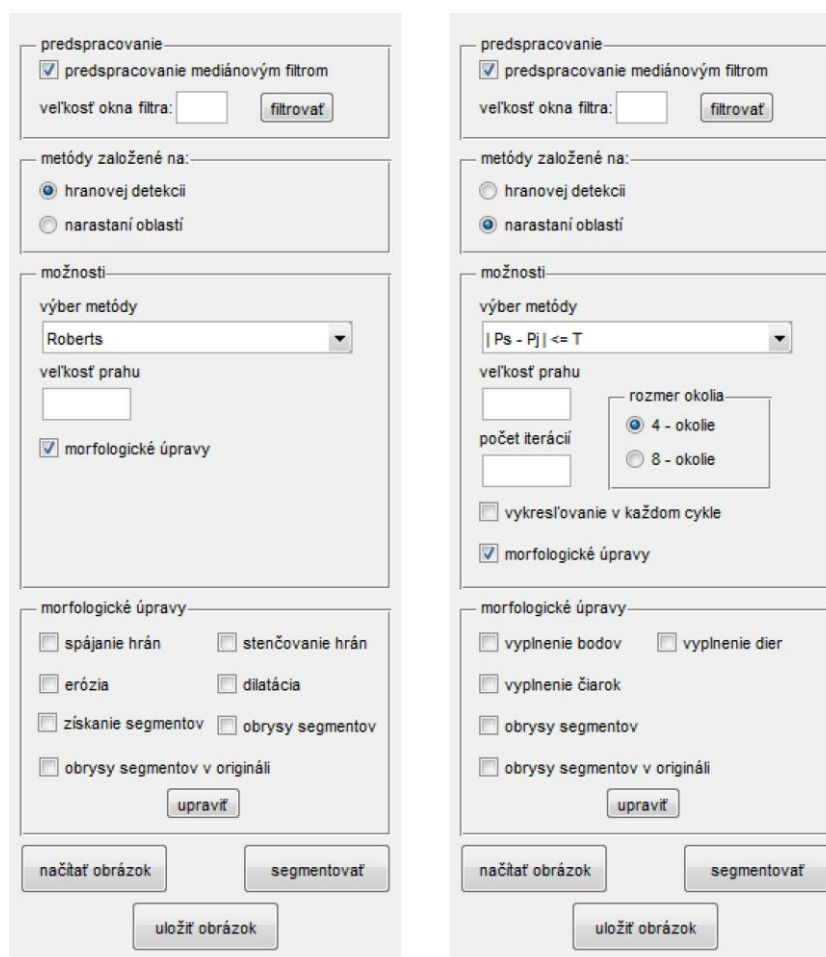
Pre úpravu segmentov získaných algoritmi narastania oblastí sú k dispozícii tri možnosti: zaplnenie bodov, zaplnenie čiarok rozmeru 1x2 alebo zaplnenie väčších oblastí vo vnútri segmentu, ktoré neboli v dôsledku šumu do segmentu priradené.

Zaplnenie bodov a čiarok je v určitom zmysle založené na dilatácii štruktúrnym elementom uvedeným na Obr. 2.10 vpravo. Zaplnenie väčších oblastí je realizované vyššie spomínanou funkciou `imfill`.

Okrem vstavanej funkcie sú všetky dostupné morfológické úpravy v programe realizované ako vlastné funkcie. Všetky sú založené na testovaní okolia pixelov podmienkami vyplývajúcimi z matematickej morfológie. Ich realizácia je zrejmá zo zdrojových kódov konkrétnych funkcií priložených na nosiči.

3.5 Vzhľad a ovládanie grafického užívateľského rozhrania

Grafické užívateľské rozhranie sa skladá z dvoch základných panelov uvedených na Obr. 3.8, v ktorých sa nastavujú parametre jednotlivých skupín metód. Panely sú v GUI umiestnené na rovnakej pozícii a v závislosti na zvolenej skupine metód sa zamieňajú. Vzhľad celého GUI je uvedený na Obr. B.1 v prílohe.



Obr. 3.8 Varianty panelov ovládania grafického užívateľského rozhrania.

Po spustení programu si užívateľ stlačením tlačidla „načítať obraz“ vyberie obraz, ktorý chce segmentovať. Ten sa následne zobrazí v paneli „vstupný/predspracovaný obraz“.

Potom si môže v paneli „predspracovanie“ zvoliť zaškrtnutím políčka predspracovanie mediánovým filtrom. Po zaškrtnutí sa zobrazí textové pole, v ktorom užívateľ zadá veľkosť okna filtra, pričom veľkosť je obmedzená na nepárne čísla od 3 do 15. V prípade zadania párneho čísla z intervalu od 3 do 16 program automaticky prepíše číslo na najbližšie nižšie nepárne číslo. Pri zadaní čísla, ktoré nepatrí do určeného intervalu alebo zadania nečíselného znaku program textové pole zmaže. Ak užívateľ stlačí tlačidlo filtrovať a textové pole je prázdne, program vypíše chybové hlásenie a na prázdne pole upozorní.

V ďalšom paneli „metódy založené na:“ si užívateľ vyberie z dvoch skupín metód, na základe čoho sa obmieňa nasledovný panel.

V prípade voľby metód založených na hranovej detekcii si užívateľ v zozname vyberie konkrétnu metódu nazvanú podľa použitého hranového detektoru. Do príslušného poľa zadá veľkosť prahu, ktorá je ako už bolo spomenuté normalizovaná na rozsah od 0 do 10. Prah nijak nemá obmedzené množstvo desatinných čísel. Obmedzený je len interval podobným spôsobom ako pri predspracovaní. Segmentácia sa zaháji stlačením tlačidla „segmentovať“ a výsledok je zobrazený v paneli „segmentovaný obraz“. Program v prípade stlačenia tlačidla segmentovať bez zadania prahu na túto chybu upozorní. Po zaškrtnutí políčka „morfologické úpravy“ sa zobrazí ďalší panel, v ktorom je možné medzi finálnymi úpravami spomenutými v predchádzajúcej kapitole voliť. Program berie do úvahy poradie v akom sú úpravy zaškrtnuté, čím je možné v prípade erózie a dilatácie realizovať otvorenie aj uzatvorenie. Ďalšie dve možnosti, ktoré v predchádzajúcej kapitole neboli spomenuté umožňujú zobrazenie obrysu výsledného segmentu – binárny obraz jeho okrajových bodov a zobrazenie tohto obrysu v pôvodnom obraze červenou farbou. Z neznámeho dôvodu sa niekedy výsledky v paneli „segmentovaný obraz“ zobrazia nepresne a súvislé hrany sú prerušované, prípadne úplne chýbajú. Užívateľ má možnosť uložiť výsledný obraz stlačením tlačidla „uložiť obraz“. V uloženom obraze je hranová reprezentácia správna. Zaškrtnuté morfologické úpravy sú realizované po stlačení tlačidla „upraviť“.


V prípade voľby metód založených na narastaní oblasti si užívateľ zvolí medzi tromi algoritmami. Následne zadá prah. Prah vyjadruje kritérium pre priradenie pixelu ako maximálny možný rozdiel jas testovaného pixelu s jasom pixelu/priemerným jasom pixelov, s ktorým je porovnávaný. Keďže má štandardný šedotónový obraz 256 odtieňov šedi, prah je obmedzený na interval od 0 do 255. Aj v tomto prípade je pole ošetrené proti zadaniu nečíselných znakov a čísel, ktoré nepatria do intervalu. Ďalším parametrom, ktorý užívateľ zadá je maximálny počet opakovaní overovania okolia vznikajúceho segmentu. Počet môže byť ľubovoľný, avšak pre úspešnú segmentáciu dostatočný. Užívateľovi je umožnené zadať počet opakovaní cyklov z dôvodu demonštrácie rozdielu rýchlosti a efektívnosti algoritmov pre štvor-okolie a osem-okolie, medzi ktorými má možnosť voliť. Ďalšou možnosťou je zaškrtnutie políčka „vykresľovanie v každom cykle“. Výberom tejto možnosti program vykresľuje výsledok každého cyklu a po jeho vykreslení oneskorí ďalší cyklus o päť stotín

sekundy. Oneskorenie je zabezpečené použitím vstavanej funkcie v tvare `pause(0.05)`. Spustenie programu s touto obmenou poskytuje názornú ukážku fungovania algoritmov.

Po zaškrtnutí políčka „morfologické úpravy“ sa tak ako v paneli pre hranovú detekciu zobrazí ďalší panel, v ktorom je možné medzi finálnymi úpravami spomenutými v predchádzajúcej kapitole voliť. Na výber sú možnosti vyplnenia bodov, čiarok a dier, ktoré v dôsledku šumu neboli do segmentu zahrnuté. Zvyšné dve možnosti a spustenie realizácie sú rovnaké ako v paneli morfologických operácií určených pre metódy založené na detekcii hrán.

4 Dosiahnuté výsledky

Algoritmy boli testované na šiestich fantómových a dvoch umelo vytvorených obrazoch. Úspešnosť segmentácie je veľmi individuálna a závisí od konkrétneho obrazu a segmentovanej oblasti, zadaných parametrov, použitia predspracovania. Výrazne lepšie výsledky boli dosiahnuté po potlačení šumu mediánovým filtrom či už pri použití hranových detektorov alebo algoritmov narastania oblasti. V umelo vytvorených obrazoch je algoritmom narastania oblasti podľa predpokladu najpresnejšie segmentovateľný kruh s najvyšším jasom a presnosť sa postupne s klesajúcim kontrastom voči pozadiu zhoršuje. Výsledky segmentácie umelo vytvoreného obrazu s rozptylom šumu $v_1 = 0,2$ s predspracovaním mediánovým filtrom s veľkosťou okna 7×7 tretím algoritmom narastania oblasti s veľkosťami prahov postupne zľava doprava: 130, 100, 44, 15, sú uvedené na Obr. 4.1. Všetky segmenty vznikli bez aplikovania morfológických úprav. Pre názornosť sú zobrazené časti pôvodného obrazu s obrysom segmentu.




Obr. 4.1 Výsledky segmentácie kruhov v umelo vytvorenom obraze od najsvetlejšieho po najtmavší algoritmom narastania oblasti. Použité prahy: 130, 100, 44, 15.

Bez predspracovania sa okraje dolných kruhov v umelo vytvorenom testovacím obraze s väčším rozptylom šumu požitím hranových detektorov v dôsledku veľkého šumu a malého kontrastu nedajú detegovať. Aplikovaním hranových detektorov na takto výrazne zašumený obraz je detegované množstvo chybných hrán vo vnútri obrazov. Pri určitom prahu je ich množstvo také vysoké, že v binárnej reprezentácii zaplňajú skoro celé vnútro objektov obrazu. To sa dá využiť a pomocou morfológických operácií zaplniť oblasti vo vnútri objektov medzi hranami. Takáto segmentácia sa však vymyká z princípu hranovej detekcie a jedná sa skôr o využitie nedostatkov nie veľmi verného modelovania specklov funkciou Matlabu. Horné dva kruhy majú kontrast dostatočne vysoký a hranové detektory pri vhodne zvolenom prahu poskytujú ich hrubú hranovú reprezentáciu. Finálna úprava hrán pomocou funkcií stenčovanie a spájanie hrán bola úspešná len v niektorých prípadoch. Viac sa osvedčilo použitie morfológickej dilatácie a erózie a v prípade súvislých hrán aj získanie segmentu pomocou funkcie `imfill`.

Úspešnosť segmentácie fantómových dát hranovými detektormi je pri ich aplikovaní na celý obraz diskutabilná. Situácia by bola iná, keby sa hrany získavali len v určitej vopred vymedzenej oblasti záujmu. Príklad hranovej reprezentácie segmentov prvého z fantómových


obrazov predspracovaného mediánovým filtrom s veľkosťou okna 9x9 po aplikovaní Sobelovho hranového detektoru s prahom 0,5 je na Obr. 4.2. Z dodatočných morfológických úprav boli v tomto prípade použité dilatácia a následné získanie segmentov vyplnením uzatvorených hrán.




Obr. 4.2 Príklad hranovej reprezentácie výsledku segmentácie prvého z fantómových obrazov po aplikovaní predspracovania, Sobelovho operátora a dodatočných úprav.

Ako už bolo spomenuté, z hľadiska teórie je pri použití hranových detektorov založených na druhej derivácii výhodnejšie využiť namiesto obyčajného prahovania absolútnej hodnoty druhej derivácie funkcie detekciu prechodu nulou, pretože ako je aj z Obr. 2.2 zrejmé, druhá derivácia obrazovej funkcie má amplitúdu oboch polvln oproti prvej derivácii približne polovičnú. Prah je teda ťažšie odhadnuteľný a odozva týchto detektorov na jednu hranu je dvojité. Realizácia detekcie prechodu nulou však bez použitia vstavanej funkcie Matlabu nie je jednoduchá. Preto bolo použité nevýhodnejšie prahovanie absolútnej hodnoty druhej derivácie a problém dvojitej odozvy na hranu je riešený aplikovaním morfológických operácií, napríklad dilatácie.

Segmentácia umelo vytvorených aj fantómových dát bola vo všeobecnosti úspešnejšia použitím algoritmov založených na narastaní oblasti. Výsledok však výrazne závisel od veľkosti prahu a umiestnenia semienka. Na Obr. 4.3 je uvedený výsledok segmentácie piateho z fantómových obrazov (*ROI_2.bmp*) po aplikácii predspracovania mediánovým filtrom veľkosti 5x5 a prvého algoritmu narastania oblasti s prahom 52 a dodatočným vyplnením „dier“. Na Obr. 4.4 je uvedený výsledok segmentácie rovnakého obrazu za rovnakých podmienok a približne rovnakým umiestnením semienka, avšak s prahom veľkosti 53.



Obr. 4.3 Príklad výsledku segmentácie modelu tkaniva v piatom z fantómových obrazov po aplikovaní predspracovania, prvého algoritmu a dodatočných úprav, prah = 52.



Obr. 4.4 Príklad výsledku segmentácie modelu tkaniva v piatom z fantómových obrazov po aplikovaní predspracovania, prvého algoritmu a dodatočných úprav, prah = 53.

Z obrázkov je zrejmé, že rozdiel prahu v jednom stupni odtieňa šedi významne ovplyvňuje úspešnosť segmentácie. Je to však prirodzenou vlastnosťou použitých algoritmov.

Záver

Cieľom tejto práce bolo zoznámiť sa s perfúznym zobrazovaním pomocou kontrastnej ultrasonografie, preštudovať segmentačné techniky ultrazvukových sekvencií a v programovom prostredí Matlab implementovať vhodné metódy na segmentáciu umelo vytvorených a fantómových dát. Práca obsahuje základný popis princípu ultrazvuku, stručný prehľad využívaných zobrazovacích módov, princíp kontrastného zobrazovania a všeobecný prehľad segmentačných techník. Implementované boli dve základné skupiny segmentačných metód s rozdielnym prístupom. Prvú skupinu tvoria metódy založené na detekcii hrán a druhú metódy využívajúce princíp narastania oblasti. Vzhľadom na použité dáta bolo pred aplikáciou samotných segmentačných algoritmov použité predspracovanie vo forme mediánovej filtrácie, ktorá je napriek svojej jednoduchosti jednou z osvedčených a najčastejšie aplikovaných metód pre potláčanie šumu charakteristického pre ultrasonografické dáta – speckle. Segmentácia umelo vytvorených aj fantómových dát bola vo všeobecnosti úspešnejšia použitím algoritmov založených na narastaní oblasti. Hranové detektory zlyhávali pri veľkom šume a malom kontraste obrazu. Tieto vlastnosti sú však pre ultrasonografické dáta typické. Ich použitie je preto v danej oblasti limitované. Metódy, ktoré boli pre segmentáciu testovacích dát zvolené, dokážu poskytnúť uspokojivý výsledok, avšak ich použitie vyžaduje prístup pokus-omyl. Pre finálne úpravy segmentov boli použité rôzne morfológické úpravy. Ďalším cieľom bolo metódy integrovať do grafického užívateľského rozhrania, ktoré značne uľahčilo obsluhu programu a zadávanie jednotlivých parametrov potrebných pre fungovanie a úspešnosť algoritmov. Pri navrhovaní grafického užívateľského rozhrania bol braný ohľad na jednoduchosť a intuitívnosť ovládania. Grafické užívateľské rozhranie realizované v programovom prostredí Matlab má však určité obmedzenia, a preto je vhodné aby si užívateľ pred použitím programu prečítal odporúčania uvedené v prílohe.

Literatúra

- [1] Hrazdira, I., Mornstein, V. Lékařská biofyzika a přístrojová technika. 1. vyd. Brno: Neptun, 2001. 381 s. ISBN 80-902896-1-4.
- [2] Navrátil, L., Rosina, J. Medicínská biofyzika. 1. vyd. Praha: Grada, 2005. 524 s. ISBN 80-247-1152-4.
- [3] Cosgrove, D., Lassau, N. Imaging of perfusion using ultrasound. Eur J Nucl Med Mol Imaging, 2010, 37, Suppl 1, 65–85.
- [4] Eliáš, P., et al. Dynamická kontrastní ultrasonografie jater. Ces Radiol, 2009, 63, 1, 34–41
- [5] Gauthier, T.P., et al., Perfusion quantification using dynamic contrast-enhanced ultrasound: The impact of dynamic range and gain on time–intensity curves. Ultrasonics, 2011, 51, 102-106
- [6] Jan, J. Medical Image Processing, Reconstruction and Restoration: Concepts and Methods. Boca Raton: Taylor & Francis Group, 2006. 730 s. ISBN: 0-8247-5849-8
- [7] Horák, K., et al. Počítačové vidění. Vysoké učení technické v Brně: Brno, 2008. 132 s.
- [8] Bartušek, D., et al. Využití ultrazvuku v diagnostice onemocnění střev. Čes a Slov Gastroent a Hepatol, 2010, 64, 4, 18–24.
- [9] Mischi, M. et al. Identification of Ultrasound Contrast Agent Dilution Systems for Ejection Fraction Measurements. IEEE transactions on ultrasonics, ferroelectrics, and frequency control, 2005, 52, 3, 410-420.
- [10] Španěl, M., Beran, V. Obrazové segmentační techniky [online]. Vysoké učení technické v Brně, Fakulta informačních technologií, 2005, [cit. 10.5.2013]. Dostupné na [www: http://www.fit.vutbr.cz/~spanel/segmentace/](http://www.fit.vutbr.cz/~spanel/segmentace/).
- [11] Noble, J. A., Boukerroui, D. Ultrasound Image Segmentation: A Survey. IEEE: Transactions on Medical Imaging 2006, 25, 8, 987-1010.
- [12] Czerwinski, R.N., et al. Ultrasound speckle reduction by directional median filtering. International Conference on Image Processing (ICIP'95), 1995, 1, 358.
- [13] Bhushan, Ch. Ultrasound Image Segmentation. Basics on Image Processing, 2009, [cit. 10.5.2013]. Dostupné na: http://www-scf.usc.edu/~cbhushan/files/Ultrasound_image_report.pdf
- [14] Houshmand, K.; Tizhoosh, H.R. Increasing segmentation accuracy in ultrasound imaging using filtering and snakes. Electrical and Computer Engineering, 2008, 1333-1336.

[15] Loupas, T.; McDicken, W.N.; Allan, P.L. An adaptive weighted median filter for speckle suppression in medical ultrasonic images. *Circuits and Systems, IEEE Transactions*, 1989, 36, 1, 129 - 135

[16] Mudrová, M. Matematická morfologie a segmentace obrazu. (prednáška). Praha: VŠCHT, 2004. Dostupné na: <http://uprt.vscht.cz/mudrova/zob/prednasky/10-MORFOLOGIE/morfologie.pdf>

[17] Blázsovits, G. Interaktívna učebnica spracovanie obrazu. Knižničné a edičné centrum FMFI UK Bratislava, 2006, [cit. 10.5.2013]. Dostupné na: <http://dip.sccg.sk/>

[18] Li, L., Ross, P., et al. A Comparative Study of Ultrasound Image Segmentation Algorithms for Segmenting Kidney Tumors. 4th International Symposium on Applied Sciences in Biomedical and Communication Technologies, 2011

Zoznam príloh

A	Elektronická časť bakalárskej práce	46
A.1	Program a testovacie dáta	46
A.1.1	Program a grafické užívateľské rozhranie.....	46
A.1.2	Pomocné funkcie	46
A.1.3	Testovacie dáta	46
A.2	Elektronická verzia bakalárskej práce	46
B	Vzhľad grafického užívateľského rozhrania	47
C	Odporúčania pre používanie programu	48

A Elektronická časť bakalárskej práce

A.1 Program a testovacie dáta

A.1.1 Program a grafické užívateľské rozhranie

- *segmentacia.m*
- *segmentacia.fig*

A.1.2 Pomocné funkcie

- *body_rg.m*
- *ciarkyE.m*
- *ciarkyN.m*
- *ciarkyS.m*
- *ciarkyW.m*
- *dilatacia.m*
- *erozia.m*
- *obrysy.m*
- *obrysy_eb.m*
- *obrysy_rg.m*
- *spajanie.m*
- *stencovanie.m*


A.1.3 Testovacie dáta

- *AIF_ROI_1.bmp*
- *AIF_ROI_2.bmp*
- *n_test_0.1.bmp*
- *n_test_0.2.bmp*
- *ROI_1.bmp*
- *ROI_2.bmp*
- *test.bmp*
- *VOF_1.bmp*
- *VOF_1.bmp*

A.2 Elektronická verzia bakalárskej práce

- *Vladimír_Gallo_BP.pdf*

B Vzhľad grafického užívateľského rozhrania



Obr. B.1 Vzhľad grafického užívateľského rozhrania GUI.

C Odporúčania pre používanie programu

Najväčším nedostatkom GUI je hlásenie chyby po kliknutí myšou mimo pole „vstupný/predspracovaný obraz“ pri zadávaní semienok alebo východiskovej oblasti. Ošetriť sa to bohužiaľ nijak jednoducho nedalo. V prípade tretieho algoritmu narastania oblasti sa po stlačení tlačidla „segmentovať“ zmení kurzor na kríž a oblasť záujmu sa postupne vymedzuje klikaním ľavého tlačidla myši. Po prejdení kurzoru na miesto prvého zadaného bodu sa kríž kurzoru zmení na kružnicu – ďalším kliknutím ľavého tlačidla sa oblasť uzatvorí. Potvrdenie výberu sa uskutoční stlačením klávesy Enter alebo dvojklikom vo vnútri vymedzenej oblasti. Pri prvých dvoch algoritmoch sa odporúča používať jedno semienko. Ich počet však nie je obmedzený a pri segmentovaní rôznych oblastí s podobným jasom je možné pre každú oblasť použiť nové semienko. Potvrdenie výberu sa aj v tomto prípade uskutoční stlačením tlačidla Enter alebo dvojklikom ľavého tlačidla myši. Do potvrdenia výberu sa však neodporúča klikať nikde inde ako v segmentovanom obraze so zámerom zadania semienok alebo vymedzenia východiskovej oblasti, pretože každý bod GUI má svoje súradnice. Po zadaní súradníc mimo axes, v ktorom je segmentovaný obraz vykreslený sa program snaží podľa týchto súradníc indexovať. Keď zistí, že matica body s takýmito súradnicami neobsahuje, hlási chybu. V takom prípade treba GUI vypnúť a znova zapnúť.

Druhým nedostatkom, ktorý v programe bohužiaľ nie je ošetrený je v prípade zmazania niektorej zo skôr zadaných morfológických úprav zmazanie poslednej pridanej, namiesto tej ktorú sa užívateľ snažil vylúčiť zo zoznamu.

Preto sa odporúča aby pri viacerých zmenách operácii užívateľ všetky možnosti postupne vymazal, alebo vypnutím a zapnutím celého panelu morfológických úprav ich zmazal naraz.

Tab. C.1 Príklady hodnôt základných parametrov

testovacie dáta	veľkosť prahu	metóda	veľkosť okna mediánového filtra	oblasť	umiestnenie semienka
AIF_ROI_1.bmp	70	prvý algoritmus rg	7	ROI	svetlá oblasť v strede
AIF_ROI_2.bmp	70	prvý algoritmus rg	7	ROI	svetlá oblasť v strede
n_test_0.2.bmp	130	tretí algoritmus rg	7	vľavo hore	stred príslušného kruhu
n_test_0.2.bmp	100	tretí algoritmus rg	7	vpravo hore	stred príslušného kruhu
n_test_0.2.bmp	44	tretí algoritmus rg	7	vpravo dole	stred príslušného kruhu
n_test_0.2.bmp	15	tretí algoritmus rg	7	vľavo dole	stred príslušného kruhu
ROI_1.bmp	60	prvý algoritmus rg	7	ROI	svetlá oblasť v strede
VOF_1.bmp	180	prvý algoritmus rg	7	VOF	svetlá oblasť v strede
n_test_0.2.bmp	5	sobel	7	vľavo hore	-
n_test_0.2.bmp	3	sobel	7	vpravo hore	-
n_test_0.2.bmp	1.3	sobel	7	vpravo dole	-
n_test_0.2.bmp	0.4	sobel	7	vľavo dole	-